

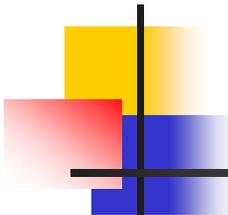
ABS : Adaptive Borders Search

Frédéric Flouvat¹

Travail réalisé avec
Fabien De Marchi² et Jean-Marc Petit¹

¹ LIMOS - Université Blaise Pascal – Clermont-Ferrand, France

² LIRIS – Université Claude Bernard – Lyon, France

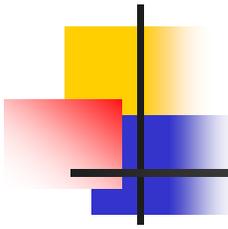


Introduction

- Travail en cours
- Deuxième année de thèse
- Objectif : Découverte des motifs fréquents maximaux d'une base de données de transactions
 - Généralisable à d'autres problèmes de fouille de données [MANNILA ET TOIVONEN 97]
 - représentable par des ensembles
 - prédicat anti-monotone

Les motifs fréquents maximaux par rapport à l'inclusion


- Permet de représenter l'ensemble des fréquents FI
- Bordure positive $Bd^+(FI)$
 - Ensemble des motifs fréquents de FI maximaux (MFI) par rapport à l'inclusion
- Bordure négative $Bd^-(FI)$
 - Ensemble des motifs non fréquents minimaux par rapport à l'inclusion



Problématique

- Performance des algorithmes de découverte des MFI
 - workshop **F**requent **I**temset **M**ining **I**mplementations 2003 (ICDM'03):
 - Apriori reste compétitif pour découvrir les MFI lorsque la taille des MFI reste « petite »
- Problème quand de grands MFI existent
- Idée d'ABS:
 - « *lorsque Apriori rencontre des difficultés, on change de stratégie* »
- Deux principaux problèmes :
 - Comment décidé dynamiquement « lorsque Apriori rencontre des difficultés »
 - Quelle stratégie ?

Exemple de découverte des MFI avec Apriori




Exemple utilisant les informations déjà découvertes



=> 1 itération au lieu de 4 iterations avec Apriori

Recherche des plus grands motifs ne comprenant pas $\{EF, FG\}$

AB AC AD AE AF AG BC BD BE BF BG CD CE CF CG DE DF DG EF EG FG



Apriori


Résultats théoriques sur les bordures (1)

- Liens entre les bordures

- Transversaux minimaux d'un hypergraphe [MANNILA ET TOIVONEN 97]

$$FI = \{ X \subseteq R \mid X \text{ est fréquent} \}$$

$$NFI = \{ X \subseteq R \mid X \text{ est non fréquent} \}$$

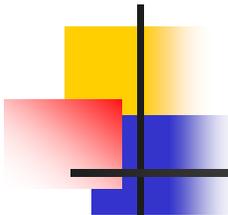


$$Bd^-(FI) = \overline{TrMin(Bd^+(FI))}$$

Résultats théoriques sur les bordures (2)

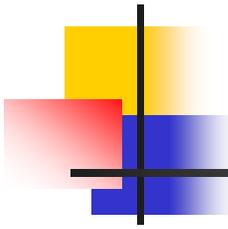
- $TrMin(TrMin(H)) = H$ [BERGE 74]
avec H un hypergraphe

- Caractérisation de la bordure positive :
 $Bd^+(FI) = TrMin(Bd(FI))$



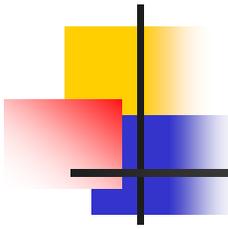
Stratégie fondée sur des dualisations

- Dualisation = calcul des transversaux minimaux
- Dans le même esprit que l'algorithme Dualize and Advance [GUNOPOULOS D. et al. 03]
- Stratégie choisie à ce jour:
 - alterne des dualisations entre les deux bordures



Intérêts de ABS

- Caractérisation exacte de la bordure positive optimiste
- Approche non fondée sur une heuristique comme MaxMiner, Mafia, GenMax
 - Prix à payer : le coût de la dualisation
- Approche adaptative
- Remarque: très sensible à la première dualisation



Comportement adaptatif

- Quand Apriori doit-il s'arrêter ?
 - Comportement adaptatif s'appuyant sur les informations déjà découvertes

 - Principaux paramètres pour un niveau k
 - Taille de la bordure négative
 - $|Bd_k^-| < |F_k|$ ou $|Bd_k^-| \approx |F_k|$
 - coût de la dualisation *vs* coût de générer et compter avec Apriori
 - Ratio $|F_k| / |C_k|$
 - Si proche de 1, dualiser doit être intéressant

- L'algorithme peut ne faire aucune dualisation, i.e. ABS = Apriori

Caractérisation des bordures

(1)

- Bordure positive optimiste Bd^+_{opt} :

- $Bd^+_{opt} = \overline{TrMin(Bd^-_k(FI))}$

avec $Bd^-_k(FI)$ l'ensemble des motifs de la bordure négative découverts à l'itération k

- $X \in Bd^+_{opt}$, X appartient au MFI ou X couvre un MFI

- Rq: plus le nombre de motifs de $Bd^-(FI)$ trouvés est important, plus on va tendre vers $Bd^+(FI)$

Caractérisation des bordures (2)


- Motifs candidats C_{i+1} :

- $C_{i+1} = \text{TrMin}(\text{Bd}^+_i(\text{FI})) - \bigcup_{j \leq i} C_j$


avec $\text{Bd}^+_i(\text{FI})$ l'ensemble des MFI découverts jusqu'à l'itération i

- Ensemble des plus petits motifs ne faisant pas partie d'une partie de l'espace de recherche déjà caractérisé


Une nouvelle stratégie




Une nouvelle stratégie




Une nouvelle stratégie

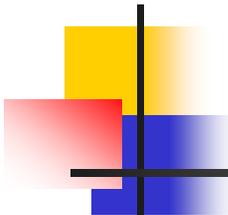


Une nouvelle stratégie




Une nouvelle stratégie





Etat de l'art (1)

- MaxMiner [BAYARDO R.J. 98]
 - Parcours par niveaux
 - "sauts" :
 - test le support du plus grand motif apparaissant dans le sous-arbre du motif en cours
 - Calcul d'une borne inférieure pour le support des candidats
- Mafia [BURDICK D. et al. 01] et Genmax [GOUDA K. et ZAKI M. 01]
 - Parcours en profondeur
 - Stratégies effectuant des sauts approximatifs
 - Différentes optimisations pour le stockage de la base de données et pour limiter la taille de l'arbre

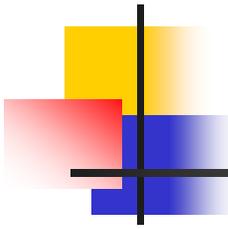


Etat de l'art (2)

- Dualize and Advance [GUNOPOULOS D. et al. 03]
 - Dualisation à partir de motifs fréquents
 - À partir du premier motif fréquent trouvé, recherche du motif fréquent maximal le couvrant par un parcours en profondeur
 - Autant d'itérations que de motifs fréquents maximaux

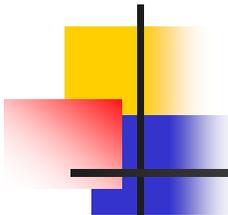
Quelques résultats expérimentaux (1)

- Implémentation en C++ s'appuyant sur les implémentations d'Apriori de C. Borgelt et B. Goethals
- Utilisation des arbres préfixés (trie) pour représenter les ensembles de motifs
- Jeux de données réels et synthétiques (FIMI)
- Pas la meilleure implémentation (FIMI'04) 🤔
 - Travail en cours
 - Comptage, dualisation... pas assez performants



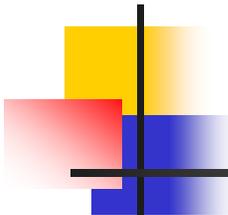
Quelques résultats expérimentaux (2)

- Mais a de meilleures performances que IBE (FIMI'03)
 - Algorithme dérivé de Dualize and Advance
 - Seule implémentation disponible utilisant le concept de dualisation
 - Le nombre de dualisation peut être amélioré
- ABS = Apriori sur le jeu de données Retail
 - Aucune dualisation n'est faite
- ABS peut améliorer Apriori par un facteur 10 sur Connect, Pumsb*




Conclusion

- Nouvelle approche adaptative qui combine la force des algorithmes
 - Apriori
 - Dualize and Advance
- Coût élevé de la dualisation pour de grands ensembles
 - Meilleure performance avec des heuristiques
- Approche générique pouvant être utilisé dans d'autres problèmes de fouille de données
 - représentable par des ensembles
 - prédicat anti-monotone
- Amélioration d'Apriori



Perspectives

- Améliorer les aspects adaptatifs
 - 1ère dualisation
 - Utiliser les MFI « presque vrais »
- Principal goulot d'étranglement pour les MFI :
 - Coût de la dualisation
- Tirer avantage des informations découvertes avant la première dualisation
 - E.g. règles d'association exactes, motifs fermés fréquents



Questions ?